

DOI:10.3876/j.issn.1000-1980.2026.04.016

基于模型降阶方法的大坝静态响应快速计算方法

程 井¹, 胡乔桦¹, 余 雷², 牛志伟¹

(1. 河海大学水利水电学院; 2. 贵州省大坝安全监测中心)

摘要:为解决孪生模型监测数据量大与高保真实时响应之间的矛盾,以拱坝为例提出了一种基于POD-RBFNN降阶模型的大坝变形快速计算方法。该方法基于有限元仿真得到的不同水位工况下的静态响应数据,通过本征正交分解(POD)法提取主导模态及模态系数,结合径向基函数神经网络(RBFNN)建立水位参数与模态系数之间的高精度代理映射,实现拱坝静态位移场的快速精准预测。算例结果表明:在仅考虑静水压力和结构自重作用条件下,POD-RBFNN降阶模型的预测结果与有限元(FEM)仿真结果吻合良好,平均相对误差为0.35%,平均绝对误差仅为0.003 2 mm,同时计算效率相较于有限元仿真提升了3 004倍。

关键词:拱坝变形;数字孪生;本征正交分解;降阶模型;径向基神经网络;快速计算

Rapid calculation method for static response of dams based on model order reduction

Cheng Jing¹, Hu Qiaohua¹, Yu Lei², Niu Zhiwei¹

(1. College of Water Conservancy & Hydropower Engineering, Hohai University;
2. Dam Safety Monitoring Center of Guizhou Province)

Abstract: To resolve the contradiction between massive monitoring data of twin models and high-fidelity rapid response, a rapid calculation method for dam deformation based on a POD-RBFNN reduced-order model was proposed taking an arch dam as an example. Based on static response data under different water level conditions obtained through finite element simulations, dominant modes and modal coefficients were extracted using the proper orthogonal decomposition (POD) method. Combined with a radial basis function neural network (RBFNN), a high-accuracy surrogate mapping between water level parameters and modal coefficients was established, achieving rapid and accurate prediction of the static displacement field of the arch dam. Calculation results show that under the condition of considering only hydrostatic pressure and structural self-weight, the prediction results of the POD-RBFNN reduced-order model agree well with finite element (FEM) simulation results, with an average relative error of 0.35% and an average absolute error of only 0.003 2 mm. Meanwhile, the calculation efficiency is improved by 3 004 times compared with the finite element simulation.

Key words: arch dam deformation; digital twin; proper orthogonal decomposition; reduced-order model; radial basis function neural network; rapid calculation

水库大坝作为国家关键基础设施,其安全稳定运行直接关系到公共安全,因此对其风险进行实时动态评估与管控已成为迫切需求^[1]。随着数字化、智能化技术的快速发展,数字孪生作为构建智慧水利体系的关键手段日益受到关注^[2]。目前数字孪生在水利工程领域尚未形成统一定义,但其核心思想已获广泛认可,即通过构建能够高保真映射物理大坝实时状态的数字仿真模型,实现对实体结构的动态模拟与状态映射^[3]。这一过程需要对不同状态下的水库大坝进行大规模的数值模拟,但确定性分析方法(有限体积法、有限差分法、有限元法等^[4])在对水库大坝此类大型且复杂的系统进行求解时,往往会因高自由度而耗费大量时间和资源,难以满足数字孪生对数据实时性的要求。因此,如何在确保数值仿真精度的同时实现计算效率的显著提升,已成为国内外亟待解决的问题^[5]。

针对复杂系统的快速求解,目前主流方法包括模型降阶法(ROM)和代理模型法。其中,模型降阶法通过构造低维基函数,将全阶模型(FOM)的高维方程投影至降阶空间,从而减少计算量,提升求解速度。根据子空间构建原理不同,主流ROM法分为本征正交分解(proper orthogonal decomposition, POD)法、模态综合

基金项目:水利部黄河流域水治理与水安全重点实验室研究基金项目(2024-SYSJJ-02);国家重点研发计划项目(2022YFC3005501);水利部重大科技项目(SKS-2022153);贵州省水利科技项目(KT202537)

作者简介:程井(1982—),男,副教授,博士,主要从事智能温控及库坝工程风险研究。E-mail:cj042@126.com

法、Krylov 子空间法等^[6-8]。这类基于物理方程投影的 ROM 法,通常高度依赖精确的物理控制方程进行降阶基的构建或投影运算,对机理不明的复杂系统适应性不足,因此限制了其工程实用价值。代理模型依靠数据驱动,通过构建输入参数与输出响应间的映射关系实现对高保真模型的近似表征,无需显式解析系统内部作用机理;但该方法对训练样本量高度敏感,同时其黑箱特性致使模型输出结果缺乏清晰的物理解释。目前主流的代理模型构建方法包括多项式响应面(response surface methodology, RSM)^[9]、径向基函数(radial basis function, RBF)^[10]、人工神经网络(artificial neural network, ANN)等^[11]。当前水利工程领域的代理模型研究主要聚焦于参数智能识别方面^[12-13],而在结构响应方面的研究较少。

综上,降阶模型与代理模型均具有一定局限性。本文提出一种适用于拱坝静态响应快速计算的数据驱动模型降阶方法,在 POD 降阶模型中内嵌代理模型,通过构建工况参数与模态系数之间的代理映射,实现拱坝静态物理场的快速精准预测,为构建其数字孪生模型提供高效核心算法。

1 数据驱动的拱坝结构位移模型降阶方法

1.1 POD 降阶模型原理

POD 降阶模型依托特征值分解手段,从高维系统样本数据中提取最优正交基向量及其对应的特征值,以此构造最小二乘投影误差最优的低维子空间。构建 POD 降阶模型,需先构建快照矩阵,其数据可源于实验、运行历史或数值仿真等,前两种获取方式普遍存在成本高、难以采集充足训练样本等问题,为此本文采用数值仿真生成所需样本数据集。通过在参数空间采样,获取各样本点数值解,并依式(1)组装快照矩阵 $\mathbf{X} \in \mathbf{R}^{M \times N}$ 。参数空间可涵盖边界条件、材料属性及时变参数等多类设计变量^[14]。

$$\mathbf{X} = [\mathbf{X}_1 \quad \mathbf{X}_2 \quad \cdots \quad \mathbf{X}_N] = \begin{bmatrix} x_{11} & \cdots & x_{1N} \\ \vdots & & \vdots \\ x_{M1} & \cdots & x_{MN} \end{bmatrix} \quad (1)$$

式中: $\mathbf{X}$ 为由 N 个快照构成的快照矩阵; $\mathbf{X}_j$ 为第 j 个实验或工况的样本向量; M 为网格节点数。针对拱坝结构孪生模型, $\mathbf{X}$ 可以为温度、渗压、应力应变等场变量,但因为位移相对稳定可靠,目前大坝安全监测一般以位移为主,其他为辅,本文以位移响应量为例开展研究。

求解 POD 模态需先获得协方差矩阵 $\mathbf{C} = \mathbf{X}\mathbf{X}^T$ 的特征向量和特征值。数值模型中网格节点数 M 通常远大于选取的快照样本数 N ,因此对矩阵 $\mathbf{C}$ 进行直接求解需要花费大量时间。鉴于协方差矩阵 $\mathbf{C}$ 与矩阵 $\mathbf{D} = \mathbf{X}^T\mathbf{X}$ 拥有相同的非零特征值,且矩阵 $\mathbf{D}$ 阶数显著低于矩阵 $\mathbf{C}$ 。因此,可以通过式(2)求解矩阵 $\mathbf{D}$ 的特征值 λ_j 及其特征向量 $\boldsymbol{\varphi}_j$,再由式(3)间接求得 $\mathbf{C}$ 对应的特征向量 $\boldsymbol{\Phi}$ 。

$$\mathbf{D}\boldsymbol{\psi} = \mathbf{A}\boldsymbol{\psi} = \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_N \end{bmatrix} [\boldsymbol{\varphi}_1 \quad \boldsymbol{\varphi}_2 \quad \cdots \quad \boldsymbol{\varphi}_N] \quad (2)$$

$$\boldsymbol{\Phi} = \mathbf{X}\boldsymbol{\psi}\mathbf{A}^{-1/2} \quad (3)$$

式中: $\mathbf{A} \in \mathbf{R}^{N \times N}$ 为特征值对角矩阵,其主对角线元素 λ_i 即第 i 阶模态的特征值,且特征值按降序排列($\lambda_1 > \lambda_2 > \cdots > \lambda_N$); $\boldsymbol{\psi}$ 为矩阵 $\mathbf{D}$ 的特征向量矩阵;其列向量 $\boldsymbol{\varphi}_i$ 为对应于特征值 λ_i 的特征向量; $\boldsymbol{\Phi}$ 为协方差矩阵 $\mathbf{C}$ 的特征向量矩阵,即 POD 模态。

一般前几阶 POD 模态携带了大部分原系统的物理信息,因此截断前 r 阶特征向量即可近似全阶模型。为量化截断误差,定义模态能量占比 $I(r)$:

$$I(r) = \frac{\sum_{i=1}^r \lambda_i}{\sum_{i=1}^N \lambda_i} \quad (4)$$

至此,全阶模型的 POD 降阶处理已完成,所得降阶子空间可表示为 $\boldsymbol{\Phi}_r$ 。在该子空间中,快照矩阵所含各快照均可由前 r 阶主导模态的线性组合近似表达:

$$\mathbf{X}_j \approx \boldsymbol{\Phi}_r \mathbf{A}_j = \sum_{i=1}^r a_{ij} \boldsymbol{\varphi}_i \quad (5)$$

式中: Φ_r 为前 r 阶模态组成的 POD 模态矩阵; $\mathbf{A}_j$ 为第 j 个快照的模态系数矩阵; a_{ij} 为第 i 阶模态的模态系数。

1.2 径向基神经网络(RBFNN)

根据 POD 基本原理,由快照矩阵分解得到的 POD 模态具备唯一解特性,但其对应的模态系数会随工况参数呈现非线性演化规律。鉴于代理模型擅长拟合复杂非线性映射关系,本文借助该优势构建工况输入参数与 POD 模态系数间的非线性映射模型,实现任意样本点处模态系数矩阵的快速预估。目前常用代理模型构建方法包括克里金模型、径向基函数模型、多项式响应面模型等,其中 RBFNN 能依托高斯核函数实现非线性映射,在兼顾模型结构简洁性的基础上,能够有效缓解高维建模过程中的维度灾难,适用于本文研究场景^[15-18]。

RBFNN 采用典型的 3 层前馈架构,由输入层、隐藏层和输出层构成,其中 $\mathbf{x}$ 为神经网络输入层; $\mathbf{h}$ 为隐藏层, y 为输出层,其基本结构如图 1 所示。RBFNN 基本形式如下:

$$y = \sum_{z=1}^m w_z h_z$$

(6)

其中 $h_z = \exp[-\|(\mathbf{x} - \mathbf{c}_z)\|^2/2b_z^2]$ ($z = 1, 2, \cdots, m$)
式中: $\mathbf{c}_z$ 、 w_z 、 b_z 分别为隐含层节点 z 中心点、权重和核宽度; h_z 为节点 z 的径向基函数。

中心点的选取需综合考虑样本规模与分布特征。对于小样本,如本文的 80 个样本,可直接采用样本点作为中心点;而对于大样本,则需通过聚类分析等方法获得少的中心点以提高优化效率。参数 b_z 的取值显著影响模型精度,因此采用优化算法对其进行自适应寻优,确保模型在不同目标函数下均能获得最优性能。权重可通过求解最小化问题确定^[19]。

1.3 基于 POD-RBFNN 的拱坝模型降阶计算方法

基于数据驱动的降阶模型可分为离线与在线两个阶段。离线阶段通过模型降阶方法构建 POD-RBF 降阶模型,在线阶段则在该降阶空间内快速求解新参数对应的解,实现对系统响应的高效预测^[20]。拱坝静态响应计算主要流程如下:①模型降阶。基于拱坝的实际运行特征,选取关键工况参数并确定采样区间,采用有限元全阶模型计算节点位移并构建位移快照矩阵,通过 POD 法提取模态与模态系数,并根据能量占比截取前 r 阶模态建立 POD 降阶模型。②代理模型训练。基于步骤①生成的样本点及其对应的前 r 阶模态系数,构建训练数据集,并采用径向基神经网络进行训练,以建立工况参数与模态系数之间的非线性映射关系。③物理场重构。将任意新工况参数输入已训练的径向基神经网络预测模态系数;再按式(5)将其与 POD 模态进行线性组合,即可获得拱坝完整结构位移响应。

2 算例验证

实验的计算平台配置如下:Windows11 操作系统,CPU 为 AMD Ryzen 9 7940H (4.00 GHz),GPU 为 NVIDIA GeForce RTX 4060,内存 16 GB。降阶模型构建与训练在 MATLAB 环境下完成。

2.1 快照矩阵构建与模型降阶

2.1.1 拱坝静态响应全阶模型

以贵州 BianY 水库拱坝为例对降阶模型进行验证。水库位于黔南州罗甸县,所在三岔河属珠江流域红水河水系。大坝为砌石混凝土拱坝,最大坝高 38.42 m,坝顶宽 3.0 m,坝顶弧长 166.8 m,坝顶高程 879.636 m,坝底厚 15.2 m,厚高比 0.396。大坝及库区周边山体的有限元模型如图 2 所示,其中坝体和坝基共离散成 55 016 个单元,60 698 个节点。坝基及坝肩四周采用法向位移约束,计算工况为正常运行状态,只考虑静水压力和自重,正常蓄水位为 878.216 m,坝前水头 37 m。坝体和坝基均采用线弹性本构模型。坝体混凝土容重为 24 kN/m³,弹性模量为 22 GPa,泊松比为 0.21。右坝肩容重为 26 kN/m³,综合变形模量为 9 GPa,泊松比为 0.25;左坝肩容重 26 kN/m³,综合变形模量为 8 GPa,泊松比为 0.25。坝基容重 27 kN/m³,综合变形模量为 52 GPa,泊松比 0.26。




图 1 径向基神经网络结构示意图
Fig.1 Schematic diagram of radial basis function neural network structure




图 2 BianY 拱坝有限元模型
Fig. 2 Finite element model of BianY arch dam

2.1.2 POD 模态分解

为突出 POD-RBFNN 降阶模型在拱坝静态响应快速预测中的有效性,仅考虑静水压力和结构自重作用下的坝体响应。选取坝前水位 H 作为关键输入参数,并结合拱坝的实测运行数据确定其参数采样区间。基于第 1.3 节降阶方法的技术框架,通过构建有限元样本集,建立代理模型。本文采用拉丁超立方采样法(LHS)生成 80 组工况样本用于构建坝体位移场快照矩阵 X 。

应用 POD 法对快照矩阵进行分解,并计算该矩阵的 POD 模态 Φ_i 及其对应特征值 λ_i 。图 3 为前 4 阶位移模态分布特征,其中 1 阶模态捕捉了拱坝整体位移的主要特征,反映了拱坝整体变形规律;随着阶数升高,模态对整体位移的贡献逐渐降低,但更能表征局部细节特征。前 20 阶特征值降序分布曲线的指数衰减趋势(图 4)表明低阶模态占据系统的主要能量;前 8 阶累计能量占比已经大于 99.99%,满足截断准则,故可将原 80 阶系统投影至 8 阶降阶子空间。进一步,依式(5)求得各阶模态对应的投影系数矩阵 A 用于构建神经网络数据集。




图 3 前 4 阶位移模态
Fig. 3 First 4 displacement modes

2.2 代理模型训练及分析

以水位为输入变量,模态系数为输出变量训练 RBFNN。将获得的 80 组模态系数作为训练集和测试集,用于确定形状参数和训练模型;额外设计 20 组独立于训练集和测试集的模态系数作为验证集,用于测试代理模型的整体效果。为评估模型质量,使用 k 折交叉验证法计算模型的均方误差。该法将样本集划分为 k 个大小相同的互斥子集,然后随机选择 $k-1$ 个子集作为训练集,其余 1 个子集作为测试集用于验证模型的预测性能。当 k 等于样本总数时,这种交叉验证称为留一法交叉验证(LOOCV)。

由图 5 可知,验证集中第 1、8、15、16 组预测相对误差较大,对其进行初步分析可知上述样本所代表的工况区域训练样本空间分布相对稀疏,致使神经网络训练过程中可获取的有效梯度信息较少,无法充分指导神经网络学习。此外神经网络算法内在的数据驱动特性,使其天然关注样本密集的核心区域,而相对忽

视样本稀疏分布的边缘地带,最终导致这些区域的预测精度有所下降。

2.3 POD-RBFNN 降阶模型效率评估

为量化评估模型全域计算精度,采用平均绝对误差 (MAE) 与平均相对误差 (MRE) 作为核心性能指标进行量化分析。为验证 POD-RBFNN 降阶模型预测结果的可靠性,基于验证集,分别采用所构建的 POD-RBFNN 降阶模型与有限元方法对拱坝进行位移场求解。通过对比两种方法获得的位移结果,系统计算了全域网格节点的平均绝对误差与相对误差,结果如图 6 所示。拱坝位移场预测的最大绝对误差为 0.003 2 mm,出现在第 8 组,对应坝前水头 $H=8.69\text{ m}$;最大相对误差为 0.35%,出现在第 15 组,对应坝前水头 $H=23.84\text{ m}$ 。




图 5 1 阶模态系数的相对误差
Fig. 5 Relative error of 1st-order modal coefficient

图 7 为验证集第 8 组和第 15 组样本的 POD-RBFNN 降阶模型与有限元方法对比云图,第 8 组最大绝对误差为 0.006 2 mm;第 15 组最大相对误差仅为 1.14%。可见,POD-RBFNN 降阶模型能够较好地反映验证样




图 7 POD-RBFNN 降阶模型与有限元方法预测位移场对比

Fig. 7 Comparison of displacement fields predicted by POD-RBFNN reduced-order model and finite element method




图 4 前 20 阶模态的特征值和累积能量占比
Fig. 4 Eigenvalues and cumulative energy ratio of first 20 modes




图 6 POD-RBFNN 降阶模型预测位移场的 MRE 和 MAE
Fig. 6 MRE and MAE of displacement field predicted by POD-RBFNN reduced-order model

本的拱坝位移场。拱坝坝顶位移是评估拱坝结构安全性的重要指标。为此,计算了验证集坝顶位移值的 MAE 与 MRE,结果如图 8 所示 POD-RBFNN 降阶模型预测的坝顶位移与有限元方法结果近乎一致,最大平均绝对误差仅有 0.004 9 mm,最大平均相对误差仅有 0.64%。

在计算效率方面,系统比较了有限元方法与 POD-RBFNN 降阶模型在验证集的计算耗时。POD-RBFNN 降阶模型的离线阶段时间包括 80 组训练样本有限元计算形成快照矩阵以及 RBFNN 代理模型训练时间两个部分。在本文计算环境下,有限元方法求解验证集 20 组样本的总耗时为 2 320 s;POD-RBFNN 降阶模型在线阶段求解 20 组样本的总耗时为 0.77 s,单次求解平均耗时 0.039 s,计算效率相较于有限元方法提升了约 3 004 倍。当计入离线阶段耗时 9284.9 s 后,POD-RBFNN 降阶模型总耗时约为有限元方法的 4 倍。

由于 POD-RBFNN 降阶模型的离线阶段耗时是固定不变的,不会随求解工况数量增加而变化。因此随着计算工况逐渐增加,POD-RBFNN 降阶模型的计算效率优势将逐渐显露。此外,在实际工程中,往往需要计算百万级单元的问题,这时有限元方法的在线计算耗时将呈指数级增长,而 POD-RBFNN 降阶模型由于仅涉及 POD 模态与系数的线性组合,其在线计算时间几乎不变。

3 结 论

- a. 应用 POD 法提取位移场的主导模态与系数,其中 1 阶模态体现了结构的整体变形行为与主要位移特征;随着模态阶数增加,各模态对系统总位移的贡献逐步递减,但其空间分布趋于复杂,能够体现拱坝局部变形细节。
- b. POD-RBFNN 降阶模型对拱坝整体位移场的预测精度与有限元方法仿真结果高度吻合,最大平均相对误差和绝对误差分别为 0.35%和 0.003 2 mm,表明该降阶模型具有良好的泛化能力。相较于有限元方法,POD-RBFNN 降阶模型单次工况求解时间仅需 0.039 s,计算效率提升了约 3 004 倍。

参考文献:

[1] 苏怀智,高建新,傅志敏,等. 梯级坝群系统服役风险评估与调控研究现状与展望[J]. 水利水电科技进展,2025,45(5):1-12. (Su Huaizhi, Gao Jianxin, Fu Zhimin, et al. Research status and prospects of service risk assessment and regulation for cascade dam systems[J]. Advances in Science and Technology of Water Resources, 2025, 45(5): 1-12. (in Chinese))

[2] 陈晓楠,靳燕国,许新勇,等. 南水北调中线干线智慧输水调度的思考[J]. 河海大学学报(自然科学版),2023,51(5):46-55. (Chen Xiaonan, Jin Yanguo, Xu Xinyong, et al. Thinking on smart water dispatching in the South-to-North Water Diversion Middle Route Project[J]. Journal of Hohai University(Natural Sciences), 2023, 51(5): 46-55. (in Chinese))

[3] Priyanka E B, Thangavel S, Gao Xiaozhi, et al. Digital twin for oil pipeline risk estimation using prognostic and machine learning techniques[J]. Journal of Industrial Information Integration, 2022, 26: 100272.

[4] Fu Rong, Liu Fang. A class of two-scale mixed finite element discretizations for the Stokes problem [J]. Bit Numerical Mathematics, 2026, 66(1): 9.

[5] 钟登华,张天鸿,余红玲,等. 智能时代与大坝工程建设智能化研究进展[J]. 水利学报, 2025, 56(1): 1-19. (Zhong Denghua, Zhang Tianhong, Yu Hongling, et al. Advancements in intelligent dam engineering construction in the intelligence era [J]. Journal of Hydraulic Engineering, 2025, 56(1): 1-19. (in Chinese))

[6] Karaduman G. Data-driven optimization of the Gamma parameter in rational Krylov subspace methods for efficient transient simulation of power delivery networks[J]. Ieee Access, 2025, 13: 194032-194047.

[7] Saletti G, Pourkiaee M, Zucca S. Mass mistuning reduced order models for bladed disks with shroud friction joints[J]. Journal of Engineering for Gas Turbines and Power-Transactions of the Asme, 2026, 148(5): 051023.

[8] 申正精,马登学,李仁年,等. 基于 POD/DMD 降阶模型的离心泵蜗壳内非稳态流动分析[J]. 哈尔滨工程大学学报, 2024, 45(10): 1974-1982. (Shen Zhengjing, Ma Dengxue, Li Rennian, et al. Analysis of unsteady flows in the volute casing of a




图 8 POD-RBFNN 降阶模型预测坝顶位移的 MRE 和 MAE

Fig. 8 MRE and MAE of dam crest displacement predicted by POD-RBFNN reduced-order model

centrifugal pump based on POD/DMD reduced order models[J]. Journal of Harbin Engineering University,2024,45(10):1974-1982. (in Chinese))

[9] 何梦佳,陈波,刘庭赫,等. 基于有限元分析的特高拱坝实时风险率模型[J]. 水利水电科技进展,2024,44(6):113-122. (He Mengjia,Chen Bo,Liu Tinghe,et al. Real-time risk rate model for extra-high arch dams based on finite element analysis[J]. Advances in Science and Technology of Water Resources,2024,44(6):113-122. (in Chinese))

[10] Tabatabaei S M,Dastourani M,Eslamian S,et al. Comparison of kriging methods in rainfall estimation based on entropy-copula (case study: Simineh river,lake Urmia Basin,Iran)[J]. Earth Science Informatics,2025,18(1):75.

[11] 李江波,罗五洲,夏旦,等. 基于自适应采样多保真度神经网络的土石坝邓肯—张 E-B 模型参数反演[J]. 水电能源科学,2025,43(4):143-146. (Li Jiangbo,Luo Wuzhou,Xia Dan,et al. Deformation prediction model of super high arch dam based on ACNN-VAR deep learning[J]. Advances in Science and Technology of Water Resources,2025,43(4):143-146. (in Chinese))

[12] Lin Chaoning,Li Tongchun,Chen Siyu,et al. Long-term viscoelastic deformation monitoring of a concrete dam; A multi-output surrogate model approach for parameter identification[J]. Engineering Structures,2022,266:114553.

[13] Dou Siqi,Li Junjie,Kang Fei. Health diagnosis of concrete dams using hybrid FWA with RBF-based surrogate model[J]. Water Science and Engineering,2019,12(3):188-195.

[14] 赵庆贤,刘云鹏,刘刚,等. 基于 POD-DNN 降阶模型的油浸式变压器绕组稳态温升快速计算方法[J]. 中国电机工程学报,2025,45(6):2423-2436. (Zhao Qingxian,Liu Yunpeng,Liu Gang,et al. Fast calculation of steady temperature rise of oil-immersed transformer windings based on POD-DNN reduced order model[J]. Proceedings of the CSEE,2025,45(6):2423-2436. (in Chinese))

[15] 谈灿灿,张润润,邓志民,等. 基于暴雨空间自相关性的降水量插值方法比较[J]. 河海大学学报(自然科学版),2024,52(6):8-14. (Tan Cancan,Zhang Runrun,Deng Zhimin,et al. Comparison of precipitation interpolation methods considering spatial autocorrelation of rainstorm precipitation[J]. Journal of Hohai University (Natural Sciences),2024,52(6):8-14. (in Chinese))

[16] Liang Jiaming,Li Zhanchao,Khailah E Y. Research on the modified surrogate model based on local RBF for concrete dam static and dynamic response analysis[J]. Frontiers in Earth Science,2023,11:1125691.

[17] 刘文博,杨喜娟,王力,等. 基于 SSA-RBFNN 的钢管混凝土界面粘结强度研究[J]. 中国安全生产科学技术,2025,21(3):148-155. (Liu Wenbo,Yang Xijuan,Wang Li,et al. Study on interfacial bond strength of concrete-filled steel tube based on SSA-RBFNN[J]. Journal of Safety Science and Technology,2025,21(3):148-155. (in Chinese))

[18] Zhou Lanting,Long Guanlin,Hu Cancan,et al. Reservoir water level prediction using combined CEEMDAN-FE and RUN-SVM-RBFNN machine learning algorithms[J]. Water Science and Engineering,2025,18(2):177-186.

[19] 崔凯,杨靖,常思源,等. 基于 POD 和代理模型的高压捕获翼表面流场快速预测方法[J]. 力学学报,2025,57(4):883-894. (Cui Kai,Yang Jing,Chang Siyuan,et al. Rapid prediction method for high-pressure capturing wing surface flow field based on proper orthogonal decomposition and surrogate model[J]. Chinese Journal of Theoretical and Applied Mechanics,2025,57(4):883-894. (in Chinese))

[20] Padula G,Girfoglio M,Rozza G. A brief review of reduced order models using intrusive and non-intrusive techniques[J]. PAMM,2024,24(4):e202400210.

(收稿日期:2025 - 07 - 29 编辑:刘晓艳)